

Труды МАИ. 2025. № 142
Trudy MAI. 2025. No. 142. (In Russ.)

Научная статья
УДК 629.78, 004.94
URL: <https://trudymai.ru/published.php?ID=185113>
EDN: <https://www.elibrary.ru/WIFOCQ>

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ АНАЛИЗА ДВИЖЕНИЯ КОСМИЧЕСКОЙ ТРОСОВОЙ СИСТЕМЫ

Акалу Йехалем Айнвага^{1✉}, Ван Чанцин², Дмитрий Валерьевич Еленев³, Лу Хонши⁴

^{1,3}Самарский национальный исследовательский университет имени академика С.П.

Королева, Самара, Россия

^{2,4}Северо-западный политехнический университет, Сиань, КНР

¹yehalemaynwagaa@gmail.com✉

²wangcq@nwpu.edu.cn

³elenev@ssau.ru

Аннотация. Рассматривается применение нейронных сетей для анализа устойчивости движения тросовой системы в атмосфере и для анализа процесса развертывания тросовой системы в атмосфере. Анализ проводится с применением многослойных нейронных сетей, методов прямого и обратного распространения ошибки, двух различных функций активации для минимизации ошибок обучения. Процесс обучения проводился с использованием различных персептронов в скрытом слое до тех пор, пока система не выдавала результаты, соответствующие ожидаемым на основе прямых расчетов. Для обучения нейросети используются входные и выходные (целевые)

данные, которые были предварительно получены с помощью численных расчетов по математической модели движения космической тросовой системы. Результаты исследований показали, что нейронная сеть после обучения проведению расчетов траектории движения тросовой системы позволяет существенно ускорить анализ устойчивости движения системы дает возможность скорректировать ошибки после обучения нейронной сети.

Ключевые слова: нейронная сеть, тросовая система, аэродинамическая стабилизация, функции активации

Для цитирования: Акалу Йехалем Айнвага, Ван Чанцин, Еленев Д.В., Лу Хонши.

Применение нейронных сетей для анализа движения космической тросовой системы //

Труды МАИ. 2025. № 142. URL: <https://trudymai.ru/published.php?ID=185113>

Original article

APPLICATION OF NEURAL NETWORKS TO THE ANALYSIS OF THE MOTION OF A SPACE TETHER SYSTEM

Akalu Yehalem Aynwaga¹, Wang Changqing², Dmitrii V. Elenev³, Lu Honshi⁴

^{1,3}Samara National Research University, Samara, Russia

^{2,4}Northwestern Polytechnical University, Xi'an, China

¹yehalemaynwagaa@gmail.com✉

²wangcq@nwpu.edu.cn

³elenev@ssau.ru

Abstract. The research considers the application of neural networks for the analysis of the stability of the tether system motion in the atmosphere and for the analysis of the tether system deployment process in the atmosphere. The analysis is performed using multilayer neural networks, forward and backward error propagation methods, and two different activation functions to minimize training errors. The training process was carried out using a different number of perceptrons in the hidden layer until the system produced results that matched those expected based on direct calculations. To train the neural network, input and output (target) data are used that were previously obtained using numerical calculations using a mathematical model of the space tether system motion. Since the motion parameters of the tether system include the parameters of two rigid bodies and the tether, it turned out to be possible to reduce the problem to training the neuron network using individual tether system parameters, primarily the angular coordinates of the bodies included in the system. The choice of angular coordinates is justified by the fact that they are decisive in the analysis of motion stability, and a conclusion about the stability of the motion is made basing on changes in their amplitudes over time. The results of the research showed that the neural network, after learning to calculate the trajectory of the motion of the tether system, allows to significantly reduce the time needed for the analysis of the stability of the system's motion and makes it possible to correct errors after learning the neural network.

Keywords: neural network, tether system, aerodynamic stabilization, mean squared error

For citation: Akalu Yehalem Aynwaga, Wang Changqing, Elenev D.V., Lu Honshi. Application of neural networks to the analysis of the motion of a space tether system. *Trudy MAI*. 2025. No. 142. (In Russ.) URL: <https://trudymai.ru/eng/published.php?ID=185113>

Введение

Применение компьютеров позволяет повысить эффективность решения сложность инженерных задач за счет применения систем автоматизированного проектирования (CAD, Computer-aided design CAD), вычислительной гидрогазодинамики (CFD, Computational Fluid Dynamics), визуализации и графического анализа. Для решения инженерных задач используются различные языки программирования и специализированные инструменты, как, например, Matlab, Mathcad, Matplotlib и др.

В настоящее время используются для решения сложных задач в различных инженерных областях, такие как, аэрокосмические техники, строительной инженерии, науке о Земле и окружающей среде [1], широко применяются инструменты, использующие нейронные сети.

Уильям Э. Фаллер и Скотт Дж. Шерск в своей статье [2] приводят ряд задач, в которых могут возникнуть проблемы в работе; например, это высокий крутящий момент на валу и рост генерируемой мощности из-за увеличения нагрузки на лопасти ветряной турбины, создание высокого прерывистого крутящего момента из-за эффекта аэродинамической неустойчивости, повреждение или потеря структуры

аэродинамического управления из-за возникновения неустойчивого поля потока и др. Проблем в работе можно избежать, если будут приняты профилактические меры на основе сведений о предварительно спрогнозированных отказах системы во время ее работы. Они в своей работе [2] предположили, что перечисленные выше проблемы могут решаться с применением нейросетевой диагностики неисправности в реальном времени и реконфигурации управления для эталонной модели в реальном времени и динамического моделирования транспортных средств нелинейной системы управления.

С конца восьмидесятых годов нейронные сети (НС) широко использовались для моделирования инженерных приложений и человеческой деятельности во многих областях науки. Главной характеристикой НС является способность учиться на опыте (используя измеренные параметры от датчиков) и примерах (генерируемые сигналы от привода или системы управления), а затем адаптировать измененные параметры прогнозируемого параметра из целевых данных [3].

Следует отметить, что НС является одним из современных инженерных инструментов в Matlab, Python, TensorFlow и других средствах моделирования и разработки программного обеспечения, которые можно использовать для прогнозирования последующих значений параметров движения космического аппарата (КА) тросовой системы в космосе, оптимизации управления и устойчивости движения систем, управления полетом спутниковой группировки, регулировки орбиты международной космической станции (МКС), и диагностирования заранее уязвимой

компоновки КА и самолета для предотвращения несчастных случаев во время эксплуатации [4, 5].

В работе [6] анализировались строительные инженерные проблемы с применением НС с многослойным персептроном и нормализованной радиальной базисной сетью (NRBF), а исследовании [7] нейросети применялись в области структурного анализа энергии. В обоих случаях результаты показали, что нейросетевая модель является более точной и дает лучшие прогнозы, чем инструмент регрессионного анализа.

Современные высокотехнологичные изделия, такие как космические аппараты, самолеты, космические тросовые системы оснащены большим, до нескольких тысяч, количеством датчиков, выполняющих измерения множества текущих параметров полета, способствующих генерации и отправке команд управления в систему. Таким образом, прогнозирование характеристик полета, анализ и оптимизация сигналов управления и устойчивость системы являются сложными проблемами, для решения которых может потребоваться прогнозирование последующего шага, в том числе с использованием нейронной сети. НС реализует достаточно простой метод определения и прогнозирования решения вышеупомянутых сложных нелинейных задач с применением существующих параметров (данных), измеряемых датчиками генерируемых команд или сигналов исполнительного механизма и системы управления.

Модель системы: в данной статье анализируется применение нейронной сети для расчета параметров движения тросовой системы, состоящей из двух твердых тел и троса,

для чего выполняется прогнозирование значений параметров движения тросовой системы. Анализ устойчивости движения данной системы во время спуска в атмосфере производился в работах [8-10], а описание математической модели системы приведено в работе [8], где получено, что динамические уравнения движения, записанные в матричной форме, имеют вид:

$$A\dot{\vec{\omega}}_i = B \quad (1)$$

где A и B – матрицы коэффициентов размерностью 9×9 и 9×1 соответственно, и данные динамические уравнения дополняются девятью кинематическими в форме Эйлера и тремя уравнениями движения центра масс системы.

Входные и целевые данные для обучения НС в данной работе взяты из исходных данных и результатов моделирования, полученных на основании работы [8].

В качестве второй исследуемой модели рассмотрим разворачивание тросовой системы на орбите [111], где аэродинамическая сила и гравитационный момент системы используются для создания оптимальной скорости разворачивания троса. Математическая модель здесь имеет следующий вид:

$$\ddot{l} = l(\dot{\varphi}^2 + 2\Omega\dot{\varphi} + \Omega^2) - \frac{GM_e(l-R)}{(l^2 - 2lR + R^2)^{\frac{3}{2}}} + \frac{Q(m_1 + m_2)}{m_1 m_2}, \quad (2)$$

$$\ddot{\varphi} = -2\frac{\dot{l}}{l}(\dot{\varphi} - \Omega) - 3\Omega^2\varphi, \quad (3)$$

где $Q = T + F_R$ - действующая внешняя сила, $F_R = -\frac{\rho V^2}{2} c_x S$ - аэродинамическая сила, V – абсолютная скорость, c_x – коэффициент аэродинамического сопротивления, S – площадь поперечного сечения тела, $\rho(h)$ – плотность атмосферы в заданной высоте,

$T = 3\Omega^2 l \frac{(m_1+m_2)}{m_1 m_2}$ – натяжение троса, $\Omega = \frac{\mu}{(R+h)^3}$ - угловая скорость, h - высота орбиты.

Совместное применение численного моделирования и обучения нейронной сети позволяет сравнивать результаты прямых расчетов с результатами обучения нейронной сети, что, в свою очередь, дает возможность предсказывать поведение системы на следующем шаге численного моделирования.

Искусственные нейронные сети (ИНС) – широко используемая технология моделирования сложных нелинейных и динамических систем. ИНС полезны при разработке подходящей модели, когда физические связи между процессами неясны или когда природа события имеет хаотические свойства. Хотя нейронная сеть требует априорной информации о системе, она снижает зависимость модели от нее. Это устраняет необходимость в точном определении конкретной функциональной формы взаимосвязи, которую модель стремится представить [11-14]. Модели ИНС способны обучаться и адаптироваться, очень эффективны для получения математической связи (соотношения) между предсказанием и откликом. Модели ИНС состоит из входного, скрытого и выходного слоя.

Данные, используемые для моделирования ИНС, делятся на обучающие, целевые и тестовые данные. Использование проверочного набора широко распространено для того, чтобы избежать переобучения, но основной объем составляю обучающие данные.

Формально обучение нейронных сетей представляет собой многопараметрическую нелинейную задачу оптимизации. Существует несколько методов обучения НС – обучение без учителя, обучение с учителями и обучение с

подкреплением. Обучение с учителями позволяет решать задачи регрессии и классификации объектов. В этом случае сеть использует массив данных, состоящий из входных и соответствующих целевых данных для настройки параметров, а обучение без учителя позволяет решать задачи кластеризации, поиска ассоциаций и снижения размерности. Обучение НС с подкреплением вырабатывают стратегию, которая приписывает состояниям среды действия, которые система должна предпринимать в этих состояниях [14-16]. В данной работе рассматриваются методы обучения с учителем.

Архитектурно НС могут быть одно- или многослойными персептронами.




Рис. 1. Структура нейронной сети (одно- и многослойной)

Многослойные персептроны нейронных сетей являются многослойные сетями с прямыми связями (рис.1), и математическое выражение многослойного персептрона представляется [12, 17-20]:

$$y_j^k = f(S_j^k + w_{0j}^k), S_j^k = f\left(\sum_{i=1}^{n^{(k-1)}} w_{ij}^k y_j^{k-1}\right), x_{ij}^{k+1} = y_j^k \quad (4)$$

где i – номер входа, j – номер нейрона в слое, k – номер слоя; w_{ij}^k – вес сигнала i -ого входа j -ого нейрона в слое k ; x_{ij}^k – i -й входной данные j -ого нейрона в слое k ; S_{ij}^k – взвешенная сумма j -ого нейрона в слое k ; w_{0j}^k – порог j -ого нейрона в слое k .

Для осуществления обучения искусственной нейронной сети с учителями требуются множества входных и целевых данных, измеренные или генерируемые датчиками, применяемыми в системе. В качестве входных данных используем $X = x(\alpha_i, \omega_i, l, V, \theta, t)$, где α_i – i -ый угол атаки, ω_i – i -я угловая скорость системы, l – длина троса, V – скорость движения системы, θ – угол отклонения системы, t – время осуществления данного эксперимента, а выходные параметры – угол атаки космического аппарата и стабилизатора α_i , зависящие от значения функции $f(S(\alpha_i, \omega_i, l, V, \theta, t))$. В данной работе объем обучающих данных составляет 70%, целевых – 15% и тестовых также 15%. Тестовый набор данных отделен от обучающего; он действует как невидимые данные для обученной модели, проверяя ее эффективность.

Обучение НС может выполняться различными алгоритмами обучения в соответствии с разными парадигмами и методами. В данной работе применяются методы прямого и обратного распространения.

Обучение нейронной сети (НС) осуществляется в следующем порядке: определяем входные данные и целевые значения, выбираем архитектуру нейронной сети – многослойная НС и определяем количество персептронов в НС; выбираем методы обучения – с учителем; функцию активации – гиперболический тангенс; выбираем минимизацию ошибки обучения – метод среднеквадратической ошибки; обучаем и

тестируем выбранные параметры и визуализируем соотношение целевого и обученного (предсказание) значения.

Обучение в описываемых далее расчетах производится при моделировании спуска тросовой системы в атмосфере с начальной высоты 100 км и с прогнозируемой длительностью 500 с.

Модель применяемой искусственной нейронной сети встроена в MATLAB R2020a. Модель является двухслойной связью с сигмоидальными скрытыми нейронами и линейным выходом, подходящая для задачи регрессии. Скрытые нейроны оказывают значительное влияние на обучение модели [13,14]. Хотя не существует конкретного правила оценки количества скрытых нейронов, используется эмпирическая формула, используемая многими исследователями [4]:

$$N_H = 0.5(N_I + N_O) + \sqrt{N_T} \quad (5)$$

где N_I , N_O , N_T и N_H - количество входных, выходных нейронов, обучающих данных и скрытых нейронов соответственно.

Обучение осуществлялось методом проб с количеством скрытых нейронов (персептронов) в интервале от 15 до 40 с отслеживанием критерия эффективности среднеквадратической ошибки

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{actu} - y_{pred})^2, \quad (6)$$

где MSE (mean squared error) – среднеквадратичная ошибка, y_{actu} – значение актуальных выходных (целевых) параметров в системе, y_{pred} – значения предсказанных выходных (обученных) параметров, $i = 1, 2, \dots, n$ – кол-во итераций в обучении.

Результаты применения нейросети

Результаты применения искусственной нейронной сети для анализа движения тросовой системы сравнивались с результатами прямых расчетов по математической модели, полученными в работах [8-10]. Для исследования обучения выбрали математическую модель тросовой системы с учетом влияния аэродинамических сил (сила сопротивления), параметры которые являются входными данными $X = x(\alpha_i, \omega_i, l, V, \theta, t)$, длина которого совпадает с числом нейронов во входном слое сети и выходным данными, соответственно, $\alpha_i = f(S(\alpha_i, \omega_i, l, V, \theta, t))$, длина которого равна числу нейронов в выходном слое сети.

Обучение НС осуществлялось с применением прямолинейной многослойной НС с методом обратного распространения ошибки. Для минимизации ошибки обучения оценивалась среднеквадратическое отклонение, а для сравнения полученных результатов применялось два типа функции активации – логистическая сигмоидальная функция (LOGSIG) и симметричная сигмоидальная функция активации (TANSIG). Процесс обучения устойчивости движением системы приведены при различных количествах персептронов – от 15 до 40 персептронов.

Для анализа применимости нейросетей в задаче моделирования движения тросовой системы в атмосфере были отдельно проведены расчеты параметров движения (угловых координат) первого и второго тел, то есть спускаемого космического аппарата и стабилизатора. Для первого тела результаты показали, что использование симметричной сигмоидальной функции активации с 35 персептронами достигает

наилучшей эффективности обучения НС, тогда как логистическая функция активации достигает наилучших показателей в 40 персептронах. Результаты обучения НС представлены на рис. 2–5, где показаны сравнения актуального с предсказанием угла атаки космического аппарата, среднеквадратические ошибки и критерии эффективности по итерациям соответственно.




Рис. 2 Результаты обучения по углу атаки КА




Рис. 3 Результаты сравнения расчетов угла атаки КА с результатами обучения




Рис. 4 Результаты регрессии предсказания в зависимости целевого значения




Рис. 5 Значение ошибки в зависимости итерации

Для второго тела – аэродинамического стабилизатора – полученные результаты в общем коррелируются с первым вариантом: использование симметричной сигмоидальной функции активации и логистической функции активации с 35 персептронами показывает наилучшую эффективность обучения НС. Графические отображения результатов расчетов с применением нейросети представлены на рис. 6–7, где показаны результаты обучения и сравнения прямых расчетов по математической модели с прогнозируемыми значениями угла атаки стабилизатора, а также среднеквадратические ошибки.




Рис. 6 Результаты обученной угла атаки стабилизатора в зависимости времени




Рис. 7 Результаты сравнений актуального с обученным углом атаки стабилизатора

Выбранные метод обучения, критерии эффективности и функции активации показали, что результат обучения НС является подходящим для моделирования исходной задачи движения связки двух тел в атмосфере. Наилучшие результаты обучения были получены с 35 персептронами при применении симметричной сигмоидальной функции активации со значением среднеквадратичной ошибки, равной 0,9842, а при применении логистической функции активации - при 40 персептронах и значением среднеквадратичной ошибки, равной 0,9834. В то же время наилучшая эффективность при обучении для второго тела связки получена с применением 35 персептронов входят для обеих симметричной сигмоидальной и логистической функции активации и значением среднеквадратичной ошибки равной 0,8089 и 0.8051 соответственно.

Для верификации выбранного подхода расчетов параметров движения тросовой системы в атмосфере с использованием нейросети была также реализована задача разворачивания тросовой системы в ходе движения в плотных слоях атмосферы. Ее

особенность по сравнению с предыдущей заключается в изменении длины троса по время движения. С использованием результатов прямых расчетов по данной модели были произведено обучение по основным параметрам, играющим важнейшую роль при исследовании движения системы в орбитальных системах координат: длина троса, угловые скорости, угол отклонения системы от местной вертикали и ее собственная угловая скорость, а также метод управления развертыванием троса на основании длины выпущенного троса и на основании значения натяжения троса. Результаты программного моделирования и обучения НС представлены на рис. 8-12, включая расчеты для длины троса, скорости развертывания, угол отклонения системы от местной вертикали, собственная угловая скорость системы, развертывания троса по длине и по натяжению троса соответственно.




Рис. 8. Сравнение результатов программного моделирования и нейронного обучения для длины троса




Рис. 9. Сравнение результатов программного моделирования и нейронного обучения для скорости разворачивания троса




Рис. 10. Результаты программного моделирования и нейронного обучения углового движения системы в зависимости временной итерации




Рис. 11. Результаты программного моделирования и нейронного обучения по угловой скорости




Рис. 12. Результаты программного моделирования и нейронного обучения по натяжению троса в задаче развертывания тросовой системы

Выводы

В данной работе для моделирования движения космических тросовых систем с помощью нейросетей применялись два типа функции активации, которые показали различные результаты обучения по сравнению с численным решением по математической модели. При обучении для задачи расчета параметров аэродинамической тросовой системы наиболее подходящей показала себя симметричная сигмоидальная функция активации (TANSIG). Переобучение модели позволяет добиться того, что результаты обучения минимизируют ошибки обучения по сравнению с предыдущими результатами, а также сокращается время процесса обучения, что приводит к выигрышу во времени расчетов.

Сравнение результатов, полученных при прямых численных расчетах и при использовании искусственных нейросетей, позволяет сделать вывод о применимости нейросетей для снижения затрат машинного времени при моделировании движения сложных механических колебательных систем, каковой является космическая тросовая система на атмосферном участке своего движения.

Список источников

1. Abdul-Wahaba S.A., Al-Alawi S.M. Assessment and prediction of tropospheric ozone concentration levels using artificial neural networks // Environmental Modelling & Software. 2002. V. 17, P. 219–228. DOI: [10.1016/S1364-8152\(01\)00077-9](https://doi.org/10.1016/S1364-8152(01)00077-9)

2. William E. Faller, Scott J. Schreck. Neural networks: application and opportunities in aeronautics // Progress in Aerospace Sciences. 1996. V. 32, P. 433-456. URL: [https://doi.org/10.1016/0376-0421\(95\)00011-9](https://doi.org/10.1016/0376-0421(95)00011-9)
3. Алексеев В.И., Шевкунов И.А. Применение нейросетевой технологии в аэрокосмической отрасли // Вестник Российского нового университета. 2020. № 4. С. 32-42. DOI: [10.25586/RNU.V9187.20.04.P.032](https://doi.org/10.25586/RNU.V9187.20.04.P.032)
4. Широбоков М.Г., Трофимов С.П. Управление формацией спутников на околоземной орбите с помощью методов машинного обучения // Препринты ИПМ им. М.В. Келдыша. 2020. № 19. URL: [http://doi.org/10.20948/prepr-2020-19](https://doi.org/10.20948/prepr-2020-19)
5. Сорокин А.В., Широбоков М.Г. Коррекция и прогнозирование орбитального движения космических аппаратов с помощью искусственных нейронных сетей // Препринты ИПМ им. М.В.Келдыша. 2018. № 198. DOI: [10.20948/prepr-2018-198](https://doi.org/10.20948/prepr-2018-198)
6. Rafiq M.Y., Bugmann G., Easterbrook D.J. Neural network design for engineering application // Computers and structures. 2001. No. 79. P. 1541-1552. DOI: [10.1016/S0045-7949\(01\)00039-6](https://doi.org/10.1016/S0045-7949(01)00039-6)
7. Aditya Kumar, Rahul Chhibber. Investigation of the wetting behavior of formulated SMAW electrode coating fluxes with regression and ANN model // Metallurgical and Materials Transactions. 2022. V. 54, P. 287-302. DOI: [10.1007/s11663-022-02689-x](https://doi.org/10.1007/s11663-022-02689-x)
8. Заболотнов Ю.М., Еленев Д.В. Движение в атмосферы тросовой системы «спускаемый аппарат – аэродинамический стабилизатор» // Известия Самарского научного центра Российской академии наук. 2006. Т 8, № 3. С. 833-840.

9. Elenev D.V., Zabolotnov Y.M. Analysis of the dynamics of the deployed aerodynamic space tether system // Cosmic Research. 2017. V. 55, No. 5. P. 371-379. DOI: [10.1134/S0010952517050057](https://doi.org/10.1134/S0010952517050057)
10. Akalu Y. Aynwaga, Elenev D.V. Stability Analysis of Motion of Tether System in Atmosphere with Variable Tether Length // Russian Engineering Research. 2024. V. 44, No. 12. P. 1701–1706.
11. Акалу Й.А., Еленев Д.В. Методы моделирования движения тросовых систем // Наука и бизнес: пути развития. 2023. № 4 (142). С. 8–11.
12. Вьюгин В.В. Математические основы машинного обучения и прогнозирования. - М.: МЦНМО, 2014. – 304 с.
13. Кириллов А.В., Деста А.Б., Дуббесса М.Х., Акалу Й.А. Применение нейронных сетей для диагностики и предупреждения отказов датчиков турбореактивного двухконтурного двигателя // Перспективы науки. 2021. №11 (146). С. 35-37.
14. Бельский А.Б. Требования к бортовым оптико-электронным средствам воздушной разведки летательных аппаратов // Труды МАИ. 2022. № 123. URL: <https://trudymai.ru/published.php?ID=165561>. DOI: [10.34759/trd-2022-123-16](https://doi.org/10.34759/trd-2022-123-16)
15. Гришеленок Д.А., Ковель А.А. Использование нейросетей в системах встроенного контроля бортовой аппаратуры космических аппаратов // Исследования наукограда. 2013. № 1. С. 9-13.
16. Дорофеев Е.А., Дынников А.И., Каргопольцев А.В., Свириденко Ю.Н., Фадеев А.С. Применение искусственных нейронных сетей для обработки и анализа данных

аэродинамического эксперимента // Ученые записки ЦАГИ. 2007. Т. XXXVIII, № 3-4. С. 111-118.

17. Соколов Д.Ю. Применение искусственной нейронной сети для решения задач прогнозирования движения наземных объектов // Труды МАИ. 2022. № 123. URL: <https://trudymai.ru/published.php?ID=165563>. DOI: [10.34759/trd-2022-123-17](https://doi.org/10.34759/trd-2022-123-17)

18. Осовский С. Нейронные сети для обработки информации. – М.: Финансы и статистика, 2004. – 343 с.

19. Ивашова Н.Д., Михайлин Д.А., Чернякова М.Е., Шаныгин С.В. Нейросетевое решение задачи оперативного планирования маршрутного полета беспилотных летательных аппаратов и назначение времени наблюдения наземных объектов с помощью нечеткой логики при отображении этих результатов на экране компьютера до вылета // Труды МАИ. 2019. № 104. URL: <http://trudymai.ru/published.php?ID=102223>

20. Christopher M. Bishop. Neural Networks for Pattern Recognition, Oxford Univ. Press, 1995, 498 p.

References

1. Abdul-Wahaba S.A., Al-Alawi S.M. Assessment and prediction of tropospheric ozone concentration levels using artificial neural networks. *Environmental Modelling & Software*. 2002. V. 17, P. 219–228. DOI: [10.1016/S1364-8152\(01\)00077-9](https://doi.org/10.1016/S1364-8152(01)00077-9)

2. William E. Faller, Scott J. Schreck. Neural networks: application and opportunities in aeronautics. *Progress in Aerospace Sciences*. 1996. V. 32, P. 433-456. URL: [https://doi.org/10.1016/0376-0421\(95\)00011-9](https://doi.org/10.1016/0376-0421(95)00011-9)
3. Alekseev V.I., Shevkunov I.A. Application of Neural Network Technology in Aerospace Industry Annotation. *Vestnik Rossiiskogo novogo universiteta*. 2020. No. 4. P. 32-42. (In Russ.). DOI: [10.25586/RNU.V9187.20.04.P.032](https://doi.org/10.25586/RNU.V9187.20.04.P.032)
4. Shirobokov M.G., Trofimov S.P. Formation control in low-Earth orbits by means of machine learning methods. *Preprinty IPM im. M.V. Keldysha*. 2020. No. 19. (In Russ.). (In Russ.). URL: [http://doi.org/10.20948/prepr-2020-19](https://doi.org/10.20948/prepr-2020-19)
5. Sorokin A.V., Shirobokov M.G. Correction and prediction of the spacecraft's orbital motion by artificial neural networks. *Preprinty IPM im. M.V.Keldysha*. 2018. No. 198. (In Russ.). DOI: [10.20948/prepr-2018-198](https://doi.org/10.20948/prepr-2018-198)
6. Rafiq M.Y., Bugmann G., Easterbrook D.J. Neural network design for engineering application. *Computers and structures*. 2001. No. 79. P. 1541-1552. DOI: [10.1016/S0045-7949\(01\)00039-6](https://doi.org/10.1016/S0045-7949(01)00039-6)
7. Aditya Kumar, Rahul Chhibber. Investigation of the wetting behavior of formulated SMAW electrode coating fluxes with regression and ANN model. *Metallurgical and Materials Transactions*. 2022. V. 54, P. 287-302. DOI: [10.1007/s11663-022-02689-x](https://doi.org/10.1007/s11663-022-02689-x)
8. Zabolotnov Yu.M., Elenev D.V. Motion in an atmosphere of tether system landing module – aerodynamic stabilizer. *Izvestiya Samarskogo nauchnogo tsentra Rossiiskoi akademii nauk*. 2006. V. 8, No. 3. P. 833-840. (In Russ.)

9. Elenev D.V., Zabolotnov Yu.M. Analysis of the dynamics of the deployed aerodynamic space tether system. *Cosmic Research*. 2017. V. 55, No. 5. P. 371-379. (In Russ.). DOI: [10.1134/S0010952517050057](https://doi.org/10.1134/S0010952517050057)
10. Akalu Y. Aynwaga, Elenev D.V. Stability Analysis of Motion of Tether System in Atmosphere with Variable Tether Length. *Russian Engineering Research*. 2024. V. 44, No. 12. P. 1701–1706.
11. Akalu I.A., Elenev D.V. Methods for modelling the motion of tether system. *Nauka i biznes: puti razvitiya*. 2023. No. 4 (142). P. 8–11. (In Russ.).
12. V'yugin V.V. *Matematicheskie osnovy mashinnogo obucheniya i prognozirovaniya*. (Mathematical foundations of machine learning and forecasting). Moscow: MTSNMO Publ., 2014. 304 p.
13. Kirillov A.V., Desta A.B., Dubbessa M.Kh., Akalu I.A. Application of neural networks for diagnosing and preventing sensor failures of a turbojet bypass engine. *Perspektivy nauki*. 2021. No. 11 (146). P. 35-37. (In Russ.)
14. Bel'skii A.B. Requirements for on-board optical-electronic means of aerial reconnaissance of aircraft. *Trudy MAI*. 2022. No. 123. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=165561>. DOI: [10.34759/trd-2022-123-16](https://doi.org/10.34759/trd-2022-123-16)
15. Grishelenok D.A., Kovel' A.A. The neural network use in internal measuring system for satellite's equipment. *Issledovaniya naukoigrada*. 2013. No. 1. P. 9-13. (In Russ.)

16. Dorofeev E.A., Dynnikov A.I., Kargopol'tsev A.V., Sviridenko Yu.N., Fadeev A.S. Application of artificial neural networks for processing and analysis of aerodynamic experiment data. *Uchenye zapiski TSAGI*. 2007. V. XXXVIII, No. 3-4. P. 111-118. (In Russ.)
17. Sokolov D.Yu. Application of artificial neural network for solving problems of forecasting the movement of ground objects. *Trudy MAI*. 2022. No. 123. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=165563>. DOI: [10.34759/trd-2022-123-17](https://doi.org/10.34759/trd-2022-123-17)
18. Osovskii S. *Neironnye seti dlya obrabotki informatsii* (Neural networks for information processing). Moscow: Finansy i statistika, 2004. 343 p.
19. Ivashova N.D., Mikhailin D.A., Chernyakova M.E., Shanygin S.V. Neural network solution of the operational planning task for unmanned aerial vehicles route flight and time setting for ground based objects observation employing the fuzzy logic while displaying these results on the computer screen prior to the start. *Trudy MAI*. 2019. No. 104. (In Russ.). URL: <http://trudymai.ru/eng/published.php?ID=102223>
20. Christopher M. Bishop. *Neural Networks for Pattern Recognition*, Oxford Univ. Press, 1995, 498 p.

Статья поступила в редакцию 27.05.2025

Одобрена после рецензирования 05.06.2025

Принята к публикации 25.06.2025

The article was submitted on-27.05.2025; approved after reviewing on 05.06.2025; accepted for publication on 25.06.2025